

PENGEMBANGAN MODEL PERAMALAN PERMINTAAN KEBUTUHAN RESELLER MENGGUNAKAN EXTREME LEARNING MACHINE DALAM KONTEKS INTELLIGENT WAREHOUSE MANAGEMENT SYSTEM (IWMS)

Tri Bowo Atmojo¹⁾, Reza Pulungan²⁾, Hermawan Syahputra³⁾

^{1,2,3)} Jurusan Ilmu Komputer dan Elektronika, Universitas Gadjah Mada

Sekip Utara, Bulaksumur, Yogyakarta Telp/Fax (0274)546194

e-mail : E-mail: tribowootmojo@gmail.com¹⁾, pulungan@ugm.ac.id²⁾, hermawansyahputra@gmail.com³⁾

Abstrak

Permintaan akan barang atau produk tertentu sering kali berubah secara cepat. Perubahan tersebut dapat berupa kenaikan atau penurunan permintaan. Banyak hal yang mendasari perubahan permintaan tersebut, antara lain pengaruh cuaca, masa promo produk, kemunculan produk baru, hari libur, dan sebagainya. Para pelaku industri sering kali menghabiskan banyak sumber daya (dapat berupa uang, waktu, tenaga, dan sebagainya) guna menghindari efek dari perubahan permintaan tersebut. Salah satu efek dari perubahan permintaan tersebut yaitu kehabisan barang persediaan atau bahkan melimpahnya barang persediaan. Salah satu cara tersebut yaitu dengan melakukan peramalan permintaan. Pelaku permintaan yang dimaksud adalah reseller. Beberapa dekade terakhir, banyak metode yang digunakan untuk memecahkan masalah perubahan permintaan. Metode yang cukup terkenal dan sering digunakan untuk melakukan peramalan adalah jaringan syaraf tiruan. Jaringan syaraf tiruan banyak digunakan karena kefleksibelan terhadap penyelesaian suatu masalah. Memperhatikan hal tersebut, dikembangkan sebuah model peramalan kebutuhan reseller menggunakan Extreme Learning Machine yang ditujukan untuk prototype Intelligent Warehouse Management System (IWMS) khususnya dalam sub-sistem Intelligent Forecasting System (IFS).

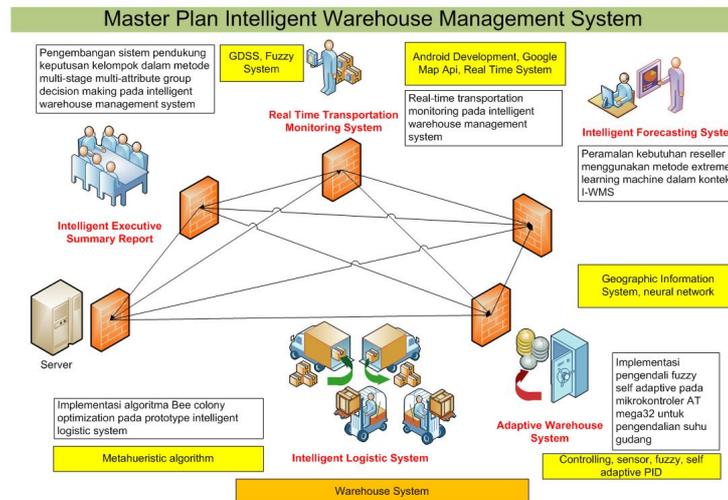
Kata Kunci : Reseller, Peramalan, jaringan syaraf tiruan, Extreme Learning Machine, moore penrose pseudoinverse.

1. PENDAHULUAN

Dewasa ini, perkembangan dunia industri menuntut para pelakunya untuk berkerja secara tepat dan cepat dalam memenuhi kebutuhan konsumen. Optimalisasi rantai pasok (*supply chain*) dari pemasok barang ke gudang (*warehouse*) dan kemudian didistribusikan ke konsumen sebagai *end user* menjadi cara ampuh untuk mewujudkan kepuasan pelayanan ditingkat konsumen. Salah satu aspek krusial dalam rangkaian rantai pasok (*supply chain*) adalah peramalan permintaan atau *demand forecasting* (Liu Guoshan, et al : 2008). Keakuratan peramalan permintaan berdampak pada ketersediaan barang yang secara tidak langsung akan mempengaruhi kelancaran proses distribusi barang ataupun biaya penyimpanan. Beberapa penelitian menyebutkan bahwa peningkatan keakuratan peramalan permintaan barang sebesar $\pm 5\%$ berkorelasi positif terhadap pelayanan permintaan barang sebesar $\pm 10\%$. Selain itu, efisiensi dan akurasi sistem peramalan permintaan barang berperan penting dalam usaha untuk meningkatkan pelayanan dan menekan biaya penyimpanan barang (Hasin M. Ahsan, et al : 2011). Beberapa dekade terakhir, banyak dilakukan pengembangan sistem peramalan permintaan yang salah satunya yaitu dengan memanfaatkan pesatnya perkembangan ilmu computer dan teknologi informasi. Salah satu gagasan pengembangan system tersebut diwujudkan dalam *prototype Intelligent Warehouse Management System (IWMS)*. Prototype tersebut merupakan sebuah system terpadu yang mampu mengendalikan proses-proses dalam rangkaian rantai pasok tersebut sehingga proses optimalisasi dapat tercapai. IWMS itu sendiri merupakan sebuah super system yang didalamnya terdiri dari 5 sistem terintegrasi yaitu *Intelligent Logistic System (ILS)*, *Adaptive Warehouse System (AWS)*, *Intelligent Forecasting System (IFS)*, *Realtime Transportation Monitoring System (RTMS)*, *Intelligent Executive Summary Report (IESS)*. Secara garis besar, arsitektur *prototype IWMS* dapat dilihat pada gambar 1.

Kelima subsistem tersebut dikembangkan sesuai dengan fungsi dan peranan masing-masing, ILS dikembangkan untuk optimalisasi penjadwalan pendistribusian barang, AWS dikembangkan untuk peningkatkan kontrol kualitas barang, RTMS untuk monitoring waktu pengiriman barang, IESS untuk membantu para manager dalam usaha pengambilan keputusan, dan IFS untuk peramalan permintaan. Sesuai dengan tujuan pengembangan sistem peramalan permintaan yaitu untuk meningkatkan tingkat akurasi hasil peramalan permintaan, pengembangan IFS berfokus pada pengembangan penggunaan metode peramalan permintaan. Usaha untuk meningkatkan tingkat akurasi peramalan telah banyak dilakukan mulai dari metode konvensional sampai dengan peramalan menggunakan metode pendekatan kecerdasan buatan (Singh Rampal and Balasundaram. S : 2007). Beberapa tahun terakhir, para peneliti banyak meneliti tentang implementasi metode-metode cabang ilmu kecerdasan buatan dalam usaha peningkatan akurasi peramalan. Salah satu

penelitian yang cukup sering dilakukan yaitu pemanfaatan jaringan syaraf tiruan (JST) untuk kasus-kasus peramalan.

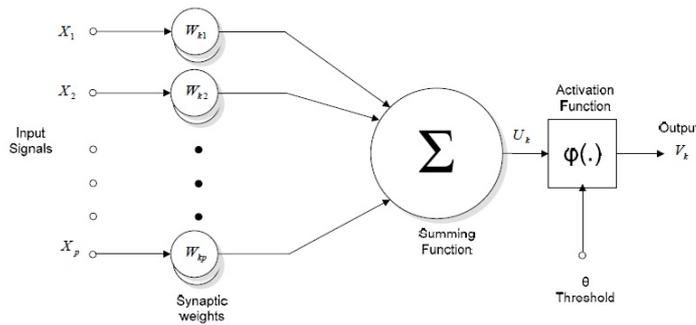


Gambar 1. Arsitektur IWMS

JST merupakan bagian dari cabang ilmu artificial intelligent yang meniru pola kerja jaringan syaraf pada makhluk hidup dalam proses penyelesaian masalah. Beragam metode telah dikembangkan dalam JST dan salah satu metode yang dikembangkan tersebut yaitu Extreme Learning Machine (ELM). Secara garis besar, ELM merupakan sebuah metode pembelajaran maju yang dikembangkan dengan memanfaatkan teori matriks pada ilmu matematika. Beberapa penelitian yang mengkaji tentang ELM antara lain : *Evolutionary Extreme Learning Machine* (Zhu Qin-Yu, et al : 2005), *Application of Extreme Learning Machine Methode for Time Series Analysis* (Balasundaram. S and Singh Rampal : 2007), *Optimization Method Based Extreme Learning Machine for Classification* (Huang Guang-Bin, et al : 2010), *Error Minimized Extreme Learning Machine With Growth of Hidden Nodes and Incremental Learning* (Feng Guorui, et al : 2009), dan sebagainya. ELM menawarkan solusi pembelajaran maju dengan waktu pembelajaran relative cepat pada jaringan syaraf tiruan. Oleh karena itu, sangat menarik untuk diteliti pengembangan model peramalan permintaan menggunakan JST dengan metode ELM pada IFS yang bertujuan untuk meningkatkan tingkat akurasi peramalan permintaan. Makalah ini terbagi terbagi menjadi 6 bagian yaitu latar belakang masalah, sekilas tentang JST, teori ELM, hasil dan perancangan, simpulan, dan daftar pustaka.

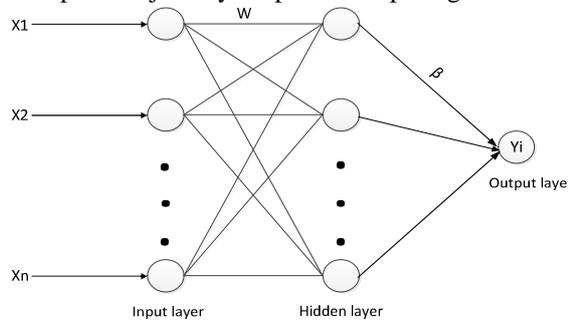
2. TINJAUAN PUSTAKA

Jaringan syaraf tiruan (JST) pertama kali diperkenalkan oleh Waren McCulloch dan logician Walter Pits pada tahun 1943. Jaringan syaraf tiruan merupakan sebuah teknik komputasi yang mengadaptasi kinerja jaringan syaraf biologis. Secara umum, JST terdiri dari 3 komponen yaitu input, neuron (fungsi penjumlah dan fungsi aktivasi), dan output yang saling terhubung. Gambar 2 model neuron pada JST secara umum. Kerja JST mengacu pada kerja jaringan mahluk hidup yang menghimpun informasi melalui lapisan input (*input layer*), kemudian informasi tersebut diproses dalam neuron menggunakan fungsi-fungsi dalam neuron tersebut kemudian hasil keluarannya diperoleh pada lapisan keluaran (*output layer*). Berdasarkan banyaknya lapisan penyusun (*layer*), JST terbagi menjadi dua kategori besar yaitu Jaringan dengan lapisan tunggal (*single layer neuron network*) dan jaringan dengan banyak layer (*multi layer neuron network*). Seperti halnya jaringan syaraf pada mahluk hidup, JST memerlukan pelatihan untuk dapat menyelesaikan suatu masalah. Metode pelatihan tersebut dapat berupa pelatihan maju (*feedforward*) ataupun pelatihan mundur (*backward*). Pembelajaran tersebut dilakukan dengan tujuan untuk mendapatkan model optimum jaringan sedemikian sehingga output yang dihasilkan mendekati target atau sesuai target. Lamanya waktu pembelajaran (*learning rate*) dipengaruhi oleh banyaknya neuron, bobot antar layer (jika jaringan tersebut adalah JST dengan banyak layer), fungsi aktivasi, dan metode pembelajaran yang digunakan.



Gambar 2. Model neuron

Salah satu metode terbaru yang menawarkan kecepatan proses pembelajaran yaitu *Extreme Learning Machine* (ELM). Metode tersebut diperkenalkan oleh Huang Guang-Bin et al pada tahun 2006 dalam penelitiannya yang berjudul *Extreme learning machine: Theory and applications*. ELM memanfaatkan teori invers matrik dalam proses pembelajarannya. Teori yang digunakan yaitu *moore penrose pseudoinverse*. Secara teori, proses pembelajaran jaringan menggunakan ELM membutuhkan waktu relatif singkat (Huang Guang-Bin, et al : 2006). ELM merupakan sebuah algoritma pembelajaran jaringan syaraf tiruan pada model jaringan single hidden layer feedforward (*single-hidden layer feedforward network/ SLFN*). Secara umum, model JST yang menggunakan ELM sebagai metode pembelajarannya dapat dilihat pada gambar 3.

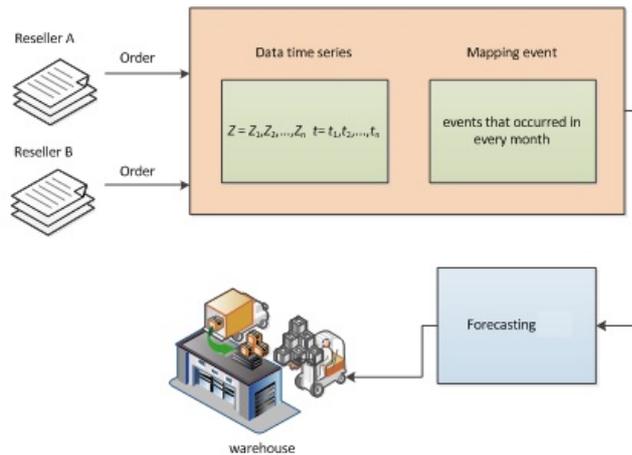


Gambar 3. Model JST dengan ELM sebagai metode pembelajarannya.

Diberikan sebuah model JST SLFN dengan n input, m neuron pada *hidden layer* dan fungsi aktivasi $g(x)$. Misalkan $X = [x_1, x_2, x_3, \dots, x_n]$ dengan x_i merupakan nilai input pada jaringan tersebut, α merupakan matriks bobot penghubung *input layer* dan *hidden layer* maka matriks α mempunyai ukuran $n \times m$. Penentuan nilai elemen-elemen matrik tersebut dilakukan secara acak. Kemudian setiap nilai input tersebut diolah pada *hidden layer* menggunakan fungsi aktivasi tertentu dan nilai tersebut dihimpun dalam sebuah matrik H dengan ordo $1 \times m$ ($H = [h_1, h_2, h_3, \dots, h_m]$). *Moore penrose pseudoinverse* digunakan untuk menentukan nilai bobot antara *hidden layer* dan *output layer* (β).

3. METODE PENELITIAN

Peramalan permintaan (*forecasting demand*) merupakan salah satu cara untuk optimalisasi manajemen rantai pasok (*supply chain*). Beberapa penelitian menyebutkan bahwa optimalisasi rantai pasok sangat penting dilakukan untuk efisiensi dan efektifitas penggunaan sumber daya. Banyak keuntungan yang dapat diperoleh dengan adanya kegiatan peramalan kebutuhan reseller yaitu perusahaan dapat menghemat biaya penyimpanan barang, perencanaan pengiriman barang menjadi lebih terkendali karena persediaan barang cenderung lebih stabil. Peramalan dilakukan dengan memperhatikan faktor-faktor yang berhubungan dengan penjualan barang seperti data series penjualan barang, adanya hari libur atau tidak, adanya masa promosi atau tidak, dan sebagainya (Hasin M. Ahsan et al, 2011).



Gambar 4. Alur kerja system peramalan kebutuhan reseller.

Optimalisasi peramalan permintaan dapat dilakukan dengan menggunakan metode peramalan tradisional seperti metode deret berkala, Akan tetapi metode ini mempunyai kekurangan jika suatu data runtun waktu (*time series*) mempunyai efek kecendrungan (*trend*) dan musiman (*seasonal*) tidak dapat memberikan hasil yang maksimal. Merujuk pada penelitian Hasin M. Ahsan et al, faktor-faktor yang dianggap mempengaruhi tingkat kebutuhan reseller yaitu masa promosi produk, adanya hari libur, dan adanya festival disamping data series penjualan dalam kurun waktu tertentu.

4. HASIL DAN PEMBAHASAN

Mengacu pada dasar teori tentang JST khususnya SLFN dan peramalan, dikembangkan sebuah model peramalan kebutuhan reseller menggunakan JST. Gambar 5 model peramalan kebutuhan reseller menggunakan ELM. Dikarenkan model tersebut menggunakan ELM sebagai metode pembelajarannya, maka jenis JST yang digunakan adalah *single-hidden layer feedforward network* (SLFN). JST tersebut terdiri dari 3 layer yaitu *input layer*, *hidden layer*, dan *output layer*. *Input layer* terdiri dari beberapa *neuron* yang merepresentasikan faktor-faktor yang dianggap mempengaruhi tingkat kebutuhan *reseller*. Banyaknya *neuron* pada *input layer* bersesuaian dengan faktor-faktor yang dianggap mempengaruhi tingkat kebutuhan *reseller*. *Layer* selanjutnya yaitu *hidden layer*, *layer* ini merupakan inti JST. Hal ini dikarenakan komputasi tahap pertama dilakukan pada *layer* tersebut. Komputasi yang dilakukan meliputi komputasi fungsi penjumlahan dan komputasi fungsi aktivasi. Nilai bobot antara *input layer* dan *hidden layer* ditentukan secara acak (pengacakan nilai bobot tersebut biasanya menggunakan pendekatan distribusi normal). Selanjutnya, proses pembelajaran JST dilakukan menggunakan *moore penrose pseudoinvers*. Input komputasi ini yaitu keluaran dari *hidden layer*. Komputasi menggunakan *moore penrose pseudoinvers* dilakukan dengan tujuan untuk menentukan bobot penghubung *hidden layer* dengan *output layer*. Selama proses pembelajaran, *output layer* berisi data target (biasanya menggunakan data penjualan pada kurun waktu tertentu).

Misalkan n adalah banyaknya faktor yang dianggap mempengaruhi kebutuhan *reseller*, m adalah banyaknya neuron pada *hidden layer*, $g(x)$ adalah fungsi aktivasi pada *hidden layer*, dan T adalah matriks target maka secara matematis model peramalan kebutuhan reseller tersebut adalah sebagai berikut :

$$X = [x_1 \quad x_2 \quad x_3 \quad \dots \quad x_n]$$

$$W = \begin{bmatrix} w_{11} & \dots & w_{1m} \\ \vdots & \ddots & \vdots \\ w_{n1} & \dots & w_{nm} \end{bmatrix}$$

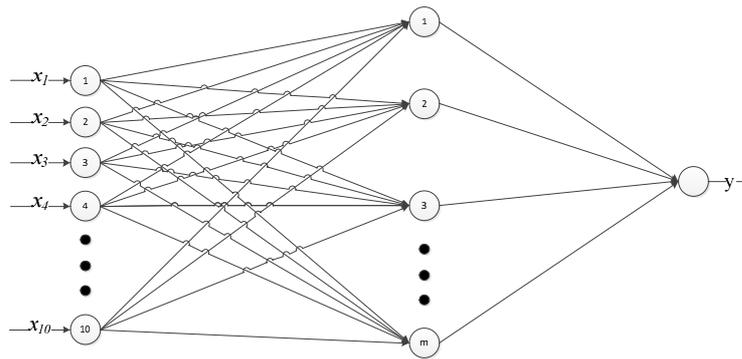
Sehingga,

$$H_{1xm} = X_{1xn} \cdot W_{nxm} \dots\dots\dots(1)$$

$$A_{1xm} = g(H) \dots\dots\dots(2)$$

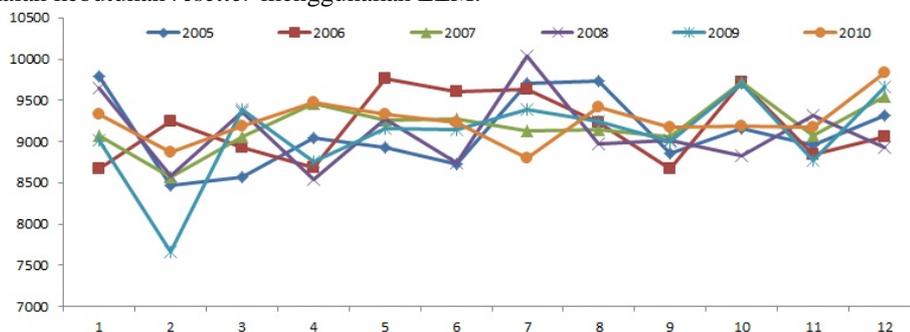
$$A^\dagger = (A^T \cdot A)^{-1} \cdot A^T \dots\dots\dots(3) \quad \text{dengan } A^\dagger \text{ adalah moore penrose pseudoinvers matriks } A$$

$$B_{1x1} = A^\dagger \cdot T \dots\dots\dots(4)$$



Gambar 5 Model peramalan kebutuhan reseller menggunakan ELM.

Pengujian model ini dilakukan menggunakan matlab 7.10. Alasan digunakannya Matlab dalam pengujian ini yaitu karena Matlab mempunyai kemampuan lebih cepat dan praktis dalam proses komputasi matriks. Pengujian tersebut menggunakan data penjualan mulai dari tahun 2005 sampai 2010 (Gambar 6), fungsi aktivasi yang digunakan adalah sigmoid, banyaknya neuron pada hidden layer yaitu 5 neuron, dan beberapa faktor yang dianggap mempengaruhi penjualan. Misalkan H adalah hari dilakukannya peramalan dan Z adalah periode waktu peramalan, Tabel 1 berikut menampilkan contoh beberapa variabel yang digunakan pada setiap layer model peramalan kebutuhan *reseller* menggunakan ELM.

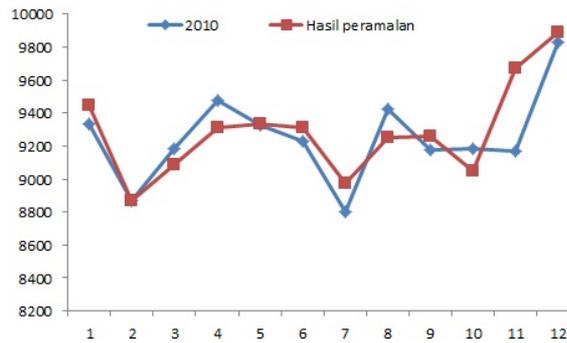


Gambar 6 Grafik penjualan 6 tahun terakhir dirinci per bulan.

Tabel 1 Variabel yang digunakan pada setiap *layer*

Input layer	Hidden layer	Output layer
x_1 = Banyaknya penjualan hari dari H-Z sampai hari dilakukannya peramalan pada tahun t.	A = Komputasi fungsi aktivasi	Y = Hasil peramalan
$x_{2,3,4}$ = Banyaknya penjualan hari dari H-Z sampai hari dilakukannya peramalan pada tahun t-1, t-2, dan t-3.		
x_5 = Banyaknya hari libur pada selang waktu H sampai dengan H+Z		
x_6 = Banyaknya masa promo produk tersebut (satuan hari)		
x_7 = Banyaknya festival pada selang waktu H sampai H+Z pada tahun t		
$x_{8,9,10}$ = Banyaknya festival pada selang waktu H sampai H+Z pada tahun t-1, t-2, dan t-3.		

Pengujian model dilakukan dengan menguji kedekatan hasil peramalan terhadap target penjualan pada tahun 2010. Berdasarkan variabel yang ditetapkan pada table 1, dan persamaan (1) sampai dengan persamaan (4) didapatkan hasil seperti pada gambar 7. Hasil pengujian tersebut menunjukkan kedekatan hasil peramalan dengan kondisi sebenarnya cukup mendekati.



Gambar 6 Grafik penjualan 6 tahun terkahir dirinci per bulan.

5. KESIMPULAN

Model peramalan kebutuhan reseller menggunakan ELM dapat dikembangkan lebih lanjut sesuai dengan kebutuhan. Bagian dari model tersebut yang dapat lebih lanjut dikembangkan antara lain banyaknya faktor yang dianggal mempengaruhi tingkat kebutuhan, banyaknya neuron pada hidden layer, dan penggunaan fungsi aktivasi. Secara umum, penggunaan JST SLFN pada model tersebut cukup efektif dalam hal pendekatan hasil peramalan terhadap target.

DAFTAR PUSTAKA

- Ghiani. G, Laporte. G, Musmanno. R, 2004, *Introduction to Logistic System Planning and Control*, John Wiley & Sons, London, England.
- Hasin M. Ahsan, Ghosh. Shuvo, Shareef. Mahmud. A, 2011, *An ANN Approach to Demand Forecasting in Retail trade in Bangladesh*, International Journal of Trade Economics and Finance Vol 2 No 2 April 2011, Page 154-160.
- Singh Rampal and Balasundaram. S, 2007, *Application of Extreme Learning Machine Methode for Time Series Analysis*, International Journal of Electrical and Computer Engineering 2:8 2007, Page 549-555.
- Halim Siana, Wibisono, Adrian Michael, 2000, *Penerapan Jaringan Syaraf Tiruan Untuk Peramalan*, Jurnal Teknik Industri Vol 2 No 2, Halaman 106-114.
- Huang Guang-Bin, Ding Xiaojian, Zhou Hongming, 2010, *Optimization Method Based Extreme Learning Machine for Classification*, Neurocomputing 74 (2010), Page 155-163.
- Zhang Yancai, Xu Hongfeng, and Zheng Yanmin, 2012, *Chinese residents' cold chain logistics demand forecasting based on GM(1,1) model*, Arican Journal of Business Management Vol 6(14), Page 5136-5141.
- Feng Guorui, Huang Guang-Bin, Lin Qingping, and Gay Robert, 2009, *Error Minimized Extreme Learning Machine With Growth of Hidden Nodes and Incremental Learning*, IEEE Tracsactions On Neural Networks Vol 20 No 8 August 2009, Page 1352-1357.
- Zhu Qin-Yu, Qin. A. K, Suganthan. P. N, 2005, *Evolutionary Extreme Learning Machine*, Pattern Recognition 38 (2005), Elsevier, Page 1759-1763.
- Huang Guang-Bin, Zhu Qin-Yu, Siew Chee-Kheong, 2006, *Extreme learning machine: Theory and applications*, Neurocomputing 70 (2006), Elsevier, Page 489-501.
- Huang Guang-Bin, Wang Dian Hui, Lan Yuan, 2011, *Extreme Learning Machine: a Survey*, Int. J. Mach. Learn. & Cyber. (2011) 2, Springer, Page 107-122.
- Pinnow Alexander, Osterburg, Stefan, Hanisch Lars, 2009, *Forecasting Demand of Potential Factors in Data Centers*, Informatika Aconomica vol 13, Page 9-15.
- Liu Guoshan, Lu Yuanyuan, 2008, *Improvement of Demand Forecasting Accuracy : A Methode Based on Region-Division*, The 7th International Symposium on Operations Research and Its Applications (ISORA'08), ORSC & APORC, Lijiang, China, Page 440-446.
- Zhang Jianyu, Pu Xuelei, Li Sheng, Yang Dan, 2004, *Logistics Forecasting Using Improved Fuzzy Neural Networks System*, The Fourth International Conference on Electronic Business (ICEB2004), Beijing, Page 1147-1150.
- Sazli Murat. H, 2006, *A brief of Feed-forward neural networks*, Commun. Fac. Sci. Univ. ANK. Series A2-A3 V.50(1). Page 11-17.